

شبکه عصبی تصمیم یاری برای تفکیک بیماری

استفاده از شبکه‌های عصبی پرسپترون چندلایه و با تابع مبتنی بر شعاع در سیستم‌های تصمیم یاری بالینی برای تفکیک دو بیماری نارسایی قلبی و انسداد مزمن ریه

سعید محرابی^۱، مهران مقصدلو^{۲*}، حسین عرب علی بیک^۳، رضوان نورمند^۴، یونس نوذری^۵

۱- دانش آموخته کارشناسی ارشد مهندسی پزشکی، دانشگاه علوم پزشکی تهران

۲- استادیار انفورماتیک پزشکی، مرکز تحقیقات علوم و تکنولوژی در پزشکی، دانشگاه علوم پزشکی تهران

۳- استادیار گروه فیزیک و مهندسی پزشکی، مرکز تحقیقات علوم و تکنولوژی در پزشکی، دانشگاه علوم پزشکی تهران

۴- دستیار گروه قلب و عروق، دانشگاه علوم پزشکی تهران

۵- دانشیار گروه قلب و عروق، دانشگاه علوم پزشکی تهران

تاریخ دریافت نسخه اصلاح شده: ۸۶/۶/۱۹ تاریخ پذیرش مقاله: ۸۶/۶/۳۱

چکیده

مقدمه: تشخیص و تصمیم گیری در مورد برخی از بیماری‌ها می‌تواند برای پزشکان در موارد خاصی، حساس و چالش‌زا باشد. سیستم‌های تصمیم یاری برای کمک به پزشکان در اتخاذ تصمیم مناسب مورد استفاده قرار گرفته و شبکه‌های عصبی به خاطر توانایی در یادگیری مسائل پیچیده با قابلیت حفظ دقت حتی در صورت نبود برخی اطلاعات، مورد توجه خاصی قرار گرفته‌اند. دو بیماری نارسایی قلبی و انسداد مزمن ریه دارای علائم مشابه بسیاری بوده و تفکیک بین این دو را برای پزشکان بویژه در هنگام پذیرش بیماران و یا در مکان‌هایی که دسترسی به اکو کاردیوگرافی وجود ندارد، مشکل می‌سازد.

مواد و روشها: ۴۳ پارامتر کلینیکی از پرونده ۲۶۶ بیمار استخراج شده و پس از مشاوره با پزشکان متخصص قلب بهنجار گردیده تا به عنوان ورودی به دو شبکه عصبی پرسپترون چند لایه و با تابع مبتنی بر شعاع داده شود. روش تنظیم بیزین برای بهبود خاصیت تصمیم شبکه پرسپترون چند لایه استفاده شد. در طراحی شبکه عصبی با تابع مبتنی بر شعاع، روش K-Means برای انتخاب مراکز توابع مبتنی بر شعاع، روش نزدیکترین همسایگی برای تعیین پراکندگی و روش سلسله مراتبی برای مشخص کردن تعداد این توابع استفاده شد. قدرت تصمیم شبکه‌های عصبی با استفاده از روش واریانس اعتبار ده لایه تخمین زده شد.

نتایج: نتایج حاصل از شبکه پرسپترون چند لایه شامل دقت ۸۳/۷٪، حساسیت ۸۸/۳٪ و ناحیه زیر منحنی ROC، 0.919 ± 0.117 می‌باشد و استفاده از شبکه عصبی با تابع مبتنی بر شعاع به دقت ۷۹/۶٪، حساسیت ۹۳٪ و ناحیه زیر منحنی ROC، 0.927 ± 0.117 منجر گردید.

بحث و نتیجه گیری: شبکه‌های عصبی به عنوان الگوریتم‌های تشخیصی در بسیاری از سیستم‌های تصمیم یاری استفاده شده و این مطالعه همانند مطالعات دیگر بر توانایی این سیستم‌ها در ارائه نتایج مناسب در تشخیص بیماری‌ها صحنه می‌گذارد. (مجله فیزیک پزشکی ایران، دوره ۳، شماره ۱۲، پاییز ۸۵: ۴۹-۶۰)

واژگان کلیدی: نارسایی قلبی، انسداد مزمن ریه، سیستم‌های تصمیم یاری بالینی، شبکه عصبی پرسپترون چند لایه، شبکه عصبی با تابع مبتنی بر شعاع

* نویسنده مسئول: مهران مقصدلو

آدرس: انتهای بلوار کشاورز، مجتمع بیمارستانی امام خمینی، تهران

کد پستی ۱۴۱۸۵۶۱۵. mmaghsoudloo@sina.tums.ac.ir

تلفن: ۰۲۱-۶۶۴۳۹۸۳۱ (۲۱) +۹۸ شماره: ۰۲۱-۶۶۴۸۶۳۰ (۲۱) +۹۸

۱- مقدمه

بیماری نارسایی قلبی^۱ یکی از بیماریهای شایع می باشد [۱-۲] و تشخیص آن به دلیل وجود علائم غیر مشخص و مشترک با بیماریهای دیگر می تواند مشکل باشد [۳-۴]. بیماری انسداد مزمن ریه^۲ علائم مشابه زیادی با نارسایی قلبی داشته و تمایز قایل شدن بین این دو بیماری را مشکل می سازد [۵].

سیستم های تصمیم یاری بالینی^۳ از پنج دهه پیش تا کنون برای کمک به پزشکان در تشخیص بیماری ها مورد استفاده قرار گرفته اند [۶]. در زمینه بیماری های قلبی یکی از اولین پروژه هایی که در تشخیص بیماری و پیش بینی اثرات معالجه به پزشکان کمک می کرد "برنامه بیماری قلبی"^۴ [۷-۹] بوده است. مطالعات دیگری با استفاده از شبکه های عصبی مصنوعی^۵ برای کمک به پزشکان در تشخیص سکته قلبی^۶ [۱۰-۱۳] بیماری رگ های قلبی^۷ [۱۴-۱۶] بیماری نارسایی قلبی [۱۷] و یا کلاسه بندی انواع بیماری های قلبی [۱۸] صورت گرفته است. اما در زمینه تمایز بین دو بیماری نارسایی قلبی و انسداد مزمن ریه تا کنون کاری صورت نگرفته است.

شبکه عصبی پرسپترون چند لایه^۸ و شبکه عصبی با تابع مبتنی شعاع^۹ در این مطالعه برای کلاسه بندی این دو بیماری مورد بررسی قرار گرفته اند.

۲- مواد و روشها

۲-۱ داده ها و شیوه بهنجارسازی^{۱۰} آنها

داده ها از پرونده بیماران بستری شده در بیمارستان امام خمینی در فاصله بین سال های ۱۳۷۸ تا ۱۳۸۴ جمع آوری شده است. تعداد ۲۶۶ بیمار با توزیع جنس و سن مطابق با جدول (۱) در این بررسی مورد مطالعه قرار گرفته اند.

۴۳ پارامتر بالینی شامل سن، جنس، علائم بیماری، معاینات پزشکی، نتایج آزمایش خون و سابقه بیماری افراد از پرونده آنها جمع آوری شده و پس از مشورت با پزشکان متخصص قلب بهنجار گردیده است (جدول ۲). پرونده بیماران معمولاً فاقد برخی پارامترهای مورد نظر در این مطالعه بوده که در این موارد، مقادیر طبیعی^{۱۱} برای آنها در نظر گرفته شده با فرض این که، اگر این پارامترها غیر طبیعی^{۱۲} بودند در پرونده بیماران منعکس می شدند [۱۹].

- 1- Congestive Heart Failure (CHF)
- 2- Chronic Obstructive Pulmonary Disorder (COPD)
- 3- Clinical Diagnostic Decision Support System
- 4- Heart Disease Program
- 5- Artificial Neural Networks
- 6- Myocardial Infarction
- 7- Coronary Artery Disease
- 8- Multilayer Perceptron
- 9- Radial Basis Function

- 10- Normalization
- 11- Normal
- 12- Abnormal

شبکه عصبی تصمیم یاری برای تفکیک بیماری

جدول ۱: توزیع جنس و سن بیماران مورد مطالعه قرار گرفته

بیماری	تعداد بیماران مرد	سن بیماران مرد	تعداد بیماران زن	سن بیماران زن
نارسایی قلبی	۶۸	۶۶/۴±۱۱/۲۹	۶۱	۶۵/۹±۱۱/۳
انسداد مزمن ریه	۷۸	۶۸/۴±۹/۰۷	۵۹	۶۷/۷۹±۱۰/۴۴

جدول ۲: پارامترهای بالینی و نحوه طبیعی کردن آنها

پارامتر	شرح	پارامتر	شرح
سن	به سال که بر ۱۰۰ تقسیم گردیده است	سابقه بیماری خانوادگی	(۰,۱)
جنس	زن (۰) مرد (۱)	بیماری فشار خون	(۰,۱)
تپش قلب	(۰,۱)	دیابت شیرین	(۰,۱)
درد ناحیه قفسه سینه	اگر به پشت و دست ها سرایت کند (۱) به خاطر ناراحتی ریوی (۰)	فشار خون	طبیعی (۰)، مرحله قبل از بیماری (۱) مرحله اول (۲) و مرحله سوم (۳) (جدول ۳)
تنگی نفس	کلاس I (۱)، کلاس II,III (۲) و کلاس IV (۳)	چربی خون	(۰,۱)
حملات تنگی نفس شبانه	(۰,۱)	علائم حیاتی به غیر از فشار خون	محدوده قابل قبول (جدول ۴) (۰) خارج از محدوده قابل قبول (۱)
ارتوپنه	(۰,۱)	وارونگی موج T درسیگنال ECG	(۰,۱)
ورم	بر اساس تعداد دست یا پاهای درگیر شده = ۱ تا ۴	صداهای قلبی	$1 = S4, S3$ $0 = S2, S1$
خستگی و ضعف	(۰,۱)	ضربان نامنظم و بالای قلبی	(۰,۱)
سیانوز	مرکزی = ۱ محیطی = ۲	فشار ورید گردنی	(۰,۱)
حالت تهوع و استفراغ	(۰,۱)	نتایج آزمایشگاهی خون شناسی	مقادیر طبیعی (مطابق جدول ۵) (۰) غیر طبیعی (۱)
دل درد	ناحیه چپ و راست بالای شکمی (۱) ناحیه چپ و راست پایین شکمی (۲)	بزرگی قلب	(۰,۱)
سرفه	(۰,۱)	سابقه مصرف سیگار	(۰,۱)
خلط	(۰,۱)	سابقه بیماری قلبی (۱)، قلبی و ریوی (۲) ریوی (۳)	
خلط خونی	(۰,۱)	سوفل سیستولی	۰ تا ۶
تب	(۰,۱)	سوفل دیاستولی	۰ تا ۱
کاهش وزن	(۰,۱)	رالز	خشن (۱) نرم (۲)
تعرق	(۰,۱)	ویز	(۰,۱)
مصرف سیگار	(۰,۱)		

((فقدان (۰) حضور (۱))

جدول ۳: رده بندی سطوح فشار خون در بزرگسالان بر اساس گزارش JNC7V [۲۰]

فشار سیستولیک (میلی متر جیوه)	فشار دیاستولیک (میلی متر جیوه)	طبقه بندی
<۱۲۰	<۸۰	طبیعی
۱۲۰-۱۳۹	۸۰-۸۹	قبل از بیماری
۱۴۰-۱۵۹	۹۰-۹۹	مرحله اول
>۱۶۰	>۱۰۰	مرحله دوم

جدول ۴: مقادیر پذیرفته شده برای علائم حیاتی

پارامتر	مقادیر پذیرفته شده
درجه حرارت	۳۶/۸ - ۳۸/۲ درجه سانتیگراد
ضربان	۶۰ - ۱۰۰ در دقیقه
نرخ تنفس	۱۵ - ۲۰ در دقیقه

جدول ۵: مقادیر طبیعی نتایج آزمایشات خون شناسی

آزمایش	مرد	زن
شمارش گلبولهای سفید	$4-10 \times 10^3$ در میکرولیتر	$4-10 \times 10^3$ در میکرولیتر
شمارش گلبولهای قرمز	$4/5-6/3 \times 10^6$ در میکرولیتر	$4/2-5/4 \times 10^6$ در میکرولیتر
میزان هموگلوبین	۱۴-۱۸ گرم بر دسی لیتر	۱۲-۱۶ گرم بر دسی لیتر
میزان هماتوکریت	۳۹-۵۲ درصد	۳۶-۴۶ درصد
شمارش پلاکتها	$150-450 \times 10^3$ در میلیمتر مکعب	$150-450 \times 10^3$ در میلیمتر مکعب

۲-۲ مدل شبکه عصبی پرسپترون چند لایه

شبکه پرسپترون چند لایه با توابع تبدیل تانژانت - سیگموئید در لایه میانی و یک نرون لگاریتم سیگموئید در لایه خروجی ساخته شد. وزن ها با استفاده از روش مقدار دهی اولیه NW^1 مقدار دهی شده است. از روش LM^۲ برای آموزش شبکه و از روش تنظیم بیزین^۳ [۲۱] برای بهبود خاصیت تعمیم آن استفاده شد.

خاصیت تعمیم در شبکه عصبی به معنی قابلیت شبکه در ارائه خروجی های قابل قبول به ازای ورودی هایی است که در آموزش شبکه شرکت نداشته اند. معمولاً برای این کار شبکه را با استفاده از بخشی از داده ها تا آنجایی آموزش می دهند که خطا بر روی بقیه داده ها که داده های اعتبارسنجی^۴ نامیده می شود به کمترین مقدار برسد. به محض افزایش مقدار خطا، آموزش را قطع می کنند. این روش نیازمند داشتن تعداد کافی

- 1- Nguyen – Windrow Initialization
- 2- Levenberg-Marquardt
- 3-Bayesian Regularization

4-Validation Data

شبکه عصبی تصمیم یاری برای تفکیک بیماری

نویز موجود در داده‌های تمرینی را نیز یاد گرفته و عملکرد مناسبی بر روی داده‌های آزمایش نداشته باشد. بنابراین هر چه شبکه با نرون‌های کمتری برای بدست آوردن جواب دلخواه استفاده شود قابلیت تعمیم شبکه نیز بالاتر خواهد رفت. تابع عملکرد (۱) علاوه بر همگرایی خروجی شبکه به مقادیر مطلوب، کاهش تعداد نرون‌ها و بزرگی وزن‌ها را نیز مد نظر قرار می‌دهد. نکته مهم در این معادله تعیین پارامترهای α و β می‌باشد که در روش تنظیم بیزین مقادیر بهینه این دو پارامتر به صورت خود کار بدست می‌آیند [۲۲].

برای انتخاب بهینه تعداد نرون‌ها در لایه میانی، تعداد نرون‌ها از یک تا بیست تغییر یافت و خطا برای داده‌های تست محاسبه گردید. تعداد نرونی که کمترین خطا را ایجاد می‌کند به عنوان مقدار بهینه در نظر گرفته شد (شکل ۱).

داده برای تقسیم آن به داده‌های آموزش و اعتبارسنجی است. یک روش دیگر برای بهبود تعمیم، اعمال تغییر به صورت زیر در تابع عملکرد^۱ شبکه می‌باشد.

$$F(W) = \alpha E_D(W) + \beta E_w(W) \quad (1)$$

که $E_D(W) = \sum_{i=1}^m (t_i - a_i)^2$ تعداد نمونه‌های آموزشی،

t خروجی مطلوب و a خروجی واقعی شبکه می‌باشند.

$E_w(W) = \frac{1}{n} \sum_{ij=1}^n w_{ij}^2$ وزن‌های شبکه و n تعداد وزن

ها می‌باشند. α و β پارامترهای قابل تنظیم هستند. اگر $\beta \gg \alpha$


الگوریتم آموزش، خطا را به کمترین مقدار می‌رساند و اگر

$\alpha \ll \beta$ تمرین بر روی کاهش وزن‌ها درازای افزایش خطا تکیه

می‌کند. هر چه شبکه عصبی پیچیده‌تر باشد و تعداد نرون‌های

بیشتری داشته باشد توانایی حل مسائل پیچیده‌تر را دارد. گاهی

افزایش بیش از اندازه تعداد نرون‌ها باعث می‌شود که شبکه



شکل ۱: خطای شبکه پرسپترون چند لایه بر روی داده‌های آموزش و تست با توجه به تعداد نرون‌ها در لایه میانی

1- Performance Function

۳-۲ مدل شبکه عصبی باتابع مبتنی بر شعاع

این شبکه عصبی از ۳ لایه ورودی، میانی و خروجی تشکیل شده است. در این شبکه، ورودی هر نرون لایه میانی، فاصله بین ورودی های شبکه و مرکز تابع تبدیل آن نرون می باشد و نرون لایه خروجی، ترکیب وزن داری از خروجی های نرونهای لایه میانی را به عنوان خروجی شبکه تولید می کند. پارامترهای این شبکه عبارت از مرکز^۱ و گستردگی^۲ توابع تبدیل لایه میانی و وزن های لایه خروجی می باشد.

می توان از توابع تبدیل مختلفی در لایه میانی استفاده کرد اما معمول ترین تابع تبدیل، تابع گوسی است.

برای انتخاب مرکز تابع گوسی از روش های مختلفی می توان استفاده کرد. ساده ترین روش این است که از داده های ورودی به عنوان مراکز این توابع استفاده کنیم. در این صورت تعمیم مناسبی برای داده های تست نخواهیم داشت. در بیشتر موارد از روش خوشه بندی K-Means استفاده می شود. از آنجایی که این روش بدون ناظر^۳ بوده و از قبل اطلاعی در مورد تعداد خوشه ها^۴ نداریم، برخی از محققین از روش های با ناظر^۵ مانند الگوریتم ژنتیک [۲۳] درخت تصمیم گیری^۱ [۲۴] و یا خوشه بندی با ناظر فازی K-Means [۲۵] استفاده کرده اند. این روش ها معمولاً زمان بر می باشند در حالیکه تمام مزیت شبکه عصبی با تابع مبتنی بر شعاع نسبت به شبکه عصبی پرسپترون چند لایه در سرعت بالای آن با ترکیب یک لایه بدون ناظر و یک لایه با ناظر می باشد. در این جا از همان روش K-Means برای انتخاب مراکز استفاده شده است. برای انتخاب تعداد نرون های

لایه میانی از روش سلسله مراتبی^۶ [۲۶] استفاده شده است بدین ترتیب که تعداد نرون ها از سه تا ده تغییر یافته و با توجه به خطای داده های تست، تعداد مناسب نرونها و به طبع آن تعداد خوشه ها انتخاب گردیده است. برای انتخاب پراکندگی از روش نزدیکترین همسایگی^۱ با توجه به فرمول زیر استفاده کردیم.

$$\sigma = \left(\frac{1}{k} \sum_{j=1}^k \|c_h - c_j\|^2 \right)^{1/2}$$

که c_j جزو مجموعه نزدیکترین همسایه ها به c_h می باشند. k برابر دو به عنوان بهترین مقدار پیشنهاد شده است [۲۷]. وزن های لایه خروجی با استفاده از روش شبه معکوس^۲ بدست می آیند.

۴-۲ روش ارزیابی و اعتبار سنجی عملکرد سیستم

برای ارزیابی میزان قدرت تعمیم شبکه طراحی شده از روش واریسی اعتبار ده لایه^۳ استفاده شد. بدین ترتیب که داده ها به صورت تصادفی به ده قسمت مساوی که در هر قسمت تعداد بیماران یکسانی از هر دو گروه وجود داشت تقسیم شدند و سپس شبکه بر روی نه قسمت از داده ها آموزش یافته و بر روی یک قسمت باقی مانده آزمایش گردید. این فرآیند ده بار تکرار شد بطوریکه خطای شبکه، میانگین این ده خطا می باشد. برای ارزیابی عملکرد شبکه در تفکیک دو بیماری از پارامترهای حساسیت^۴ و دقت^۵ استفاده می شود.

7- Forward Selection
1- Nearest Neighborhood
2- Pseudo Inverse
3- 10-Fold CrossValidation
4- Sensitivity
5- Specificity

1- Center
2- Spread
3- Unsupervised
4- Clusters
5- Supervised
6- Decision Tree

شبکه عصبی تصمیم یاری برای تفکیک بیماری

فقط موازنه ای بین حساسیت و دقت ایجاد می کند. از این رو بهترین روش برای مشخص کردن کیفیت یک تست، نشان دادن مقادیر حساسیت و دقت برای مقادیر مختلف آستانه می باشد که این رابطه بوسیله منحنی ROC نمایش داده می شود.

۳- نتایج

خروجی شبکه عصبی مقادیری بین صفر و یک است. در اینجا صفر به معنی بیماری نارسایی قلبی و یک به معنی بیماری انسداد مزمن ریه فرض شده است. خروجی مطلوب شبکه مطابق با تصمیم نهایی پزشکان، از پرونده بیماران استخراج گردیده است. با استفاده از نرم افزار MedCalc آستانه های متفاوت بین صفر و یک انتخاب شده و آستانه ای که مقادیر حساسیت و دقت را به حداکثر می رساند به عنوان آستانه مناسب در نظر گرفته شده است [۲۸].

نتایج حاصل از استفاده از شبکه عصبی پرسپترون چند لایه برای ۹ نرون در لایه میانی (شکل ۱) با آستانه ۰/۲۲۸ شامل دقت ۸۳/۷٪، حساسیت ۸۸/۳٪ و ناحیه زیر منحنی ROC، 0.91 ± 0.07 می باشد و استفاده از شبکه عصبی با تابع مبتنی بر شعاع با $K=9$ (شکل ۲) و آستانه ۰/۵۶۸۸، به دقت ۷۹/۶٪، حساسیت ۹۳٪ و ناحیه زیر منحنی ROC، 0.92 ± 0.07 منجر گردید.

حساسیت احتمال صحیح بودن تشخیص بیماری افراد بیمار است و از رابطه زیر محاسبه می شود


$$\text{حساسیت} = \frac{\text{تعداد بیمارانی که به درستی بیمار تشخیص داده شده اند}}{\text{تعداد کل بیماران}}$$

دقت احتمال صحیح بودن تشخیص سلامتی افراد سالم است و از رابطه زیر محاسبه می شود

$$\text{دقت} = \frac{\text{تعداد افراد سالم که به درستی سالم تشخیص داده شده اند}}{\text{تعداد کل افراد سالم}}$$

مقادیر حساسیت و دقت یک آزمایش با خروجی های پیوسته بین صفر و یک، بستگی به آستانه انتخاب شده بین صفر و یک برای تفکیک نتایج دارد. انتخاب این آستانه با توجه به بیماری و درمان می تواند متغیر باشد. اگر بیماری خطرناک و درمان بیمار امکان پذیر باشد، مقادیر خطای تشخیص سالم بودن فرد بیمار، بایستی کاهش پیدا کند (حساسیت بیشتر). اگر بیماری خطرناک نبوده بلکه درمان، خطر بالایی برای فرد دارد مقادیر خطای تشخیص بیمار بودن فرد سالم بایستی کاهش پیدا کند (دقت بیشتر).


بنابراین حساسیت و دقت به تنهایی مشخص کننده کیفیت یک آزمایش نمی باشند، بلکه آستانه انتخاب شونده برای تعیین نتایج نیز در آن تاثیر گذار است. تغییر آستانه تاثیری بر آزمایش ندارد بلکه



شکل ۲: خطای شبکه عصبی با تابع مبتنی بر شعاع با توجه به تعداد خوشه ها

جدول ۶: مقایسه بین دو مدل شبکه عصبی

مدل شبکه عصبی	دقت (%)	حساسیت (%)	ناحیه زیر منحنی ROC (%)
پرسپترون چند لایه	۸۳/۷	۸۸/۳	۹۱/۹±۱/۷
با تابع مبتنی بر شعاع	۷۹/۶	۹۳	۹۲/۷±۱/۷



شکل ۳: منحنی ROC برای شبکه های عصبی پرسپترون چند لایه (خط ممتد) و با تابع مبتنی بر شعاع (خط چین)

بین دو بیماری بیشترین تاثیر را دارند باعث کاهش حجم ورودی داده ها به شبکه عصبی و کاستن پیچیدگی آن می شود. روش های متفاوتی برای انتخاب بهترین پارامترها وجود دارد از جمله الگوریتم ژنتیک که در کار های آتی مورد بررسی قرار خواهد گرفت. همچنین جمع آوری داده های بیشتر بخصوص انتخاب بیمارانی که هر دو بیماری را دارند به عنوان گام بعدی در راستای بهبود اعتبار سنجی روش های پیشنهادی (فعلی و آتی) مد نظر قرار خواهد گرفت.

۴- بحث و نتیجه گیری

بیماری نارسایی قلبی معمولاً در ۲۰٪ تا ۳۰٪ موارد در بیماران دارای بیماری انسداد مزمن ریه وجود دارد [۲۹-۳۰] و از آنجایی که تنگی نفس یک علامت شناخته شده بیماری انسداد مزمن ریه می باشد نارسایی قلبی در این بیماران می تواند بدون تشخیص باقی بماند. اگر چه تشخیص نارسایی قلبی با اکوکاردیوگرافی^۱ امکان پذیر است اما این وسیله به صورت معمول توسط متخصصان ریه استفاده نمی شود. همچنین امکان دسترسی به آن برای بیماران در هنگام پذیرش محدود است. اندازه گیری BNP^۲ در پلاسما نیز می تواند به تشخیص نارسایی قلبی همراه با بیماری انسداد مزمن ریه کمک کند اما متدهای غیر تهاجمی^۳ مطلوب تر بوده و بیشتر مورد توجه قرار می گیرد. بنابراین نیاز به حضور سیستم های تصمیم یاری برای کمک به پزشکان در تشخیص و افتراق دو بیماری نارسایی قلبی و انسداد مزمن ریه مشاهده می شود [۳۱-۳۲].

در این مطالعه ۴۳ پارامتر بالینی از پرونده ۲۶۶ بیمار استخراج گردید و بعد از بهنجارسازی به عنوان ورودی شبکه عصبی استفاده شد. نتایج حاصل از دو شبکه عصبی پرسپترون چند لایه و شبکه عصبی با تابع مبتنی بر شعاع از لحاظ آماری تفاوت قابل توجهی نداشتند اگرچه شبکه عصبی با تابع مبتنی بر شعاع ساختار بسیار ساده تری نسبت به شبکه پرسپترون چند لایه داشته و مدت زمان کمتری صرف آموزش و تعیین پارامترهای آن گردید. با توجه به اینکه روش های متنوعی برای تعیین پارامترهای شبکه عصبی با تابع مبتنی بر شعاع وجود دارد همچنان جای تحقیق برای انتخاب بهترین روش آموزش وجود دارد. انتخاب پارامترهایی که در افتراق

1-Echocardiography

2- B- Type Natriuretic Peptide

3- Non- Invasive

منابع

1. Hunt SA, Abraham WT, Chin MH, Feldman AM, Francis GS, Ganiats TG, et al. ACC/AHA 2005 guideline update for the diagnosis and management of chronic heart failure in the adult. *Circulation* 2005; 112:154-235.
2. Swedberg K, Cleland J, Dargie H, Drexler H, Follath F, Komajda M, et al. Guidelines for diagnosis and treatment of chronic heart failure. *Eur Heart J* 2005; 26(11):1115-40.
3. Skaner Y, Bring J, Ullman B, Strender LE. Heart failure diagnosis in primary health care: clinical characteristics of problematic patients. A clinical judgment analysis study. *Fam Pract* 2003; 4:12.
4. Fuat A, Hungin APS, Murphy JJ. Barriers to accurate diagnosis and effective management of heart failure in primary care: qualitative study. *BMJ* 2003; 326:196.
5. Dahlstrom. Frequent non-cardiac comorbidities in patients with chronic heart failure. *Eur J Heart Fail* 2005; 7:309-316.
6. Berner ES. *Clinical decision support systems: theory and practice*, New York: Springer-Verlag 1999; 4-34.
7. Long WJ. Flexible reasoning about patient management using multiple models. *Artif Intell Med* 1991; 3:3.
8. Long WJ. Medical diagnosis using a probabilistic causal network. *Appl Artif Intell*. 1989; 3:367.
9. Long WJ. Development of a knowledge base for diagnostic reasoning in cardiology. *J Biomed Inform* 1992;25:292-311.
10. Eggers KM, Ellenius J, Dellborg M, Groth T, Oldgren J, Swahn E, et al. Artificial neural network algorithms for early diagnosis of acute myocardial infarction and prediction of infarct size in chest pain patients. *Int J Cardiol* 2007; 114:366-374.
11. Pedersen SM, Joegensen JS, Pedersen JB. Use of neural networks to diagnose acute myocardial infarction. II. A clinical application. *Clin Chem* 1996; 42(4):613-617.
12. Ellenius J, Groth T, Lindahl B, Wallentin L. Early assessment of patients with suspected acute myocardial infarction by biochemical monitoring and neural networks analysis. *Clin Chem* 1992;43(10):1919-1925.

13. Baxt WG, Shofer FS, Sites FD, Hollander JE. A neural computational aid to the diagnosis of acute myocardial infarction. *Ann Intern Med* 1991; 115:843-848.
14. Lewenstein K. Radial basis function neural network approach for the diagnosis of coronary artery disease based on the standard ECG exercise test. *Med Biol Eng Comput* 2001; 39:1-6.
15. Mobley BA, Schechter E, Moore WE, Mckee PA, Eichner JE. Predictions of coronary stenosis by artificial neural network. *Artif Intell Med* 2000;18:187-203.
16. Shen Z, Clarke M, Jones R, Alberti T. A new neural network structure for detection of coronary heart disease. *Neural Comput & Applic* 1995; 3:171-177.
17. Leslie SJ, Hartswood M, Meurig C, Mckee SP, Slack R, Procter R, et al. Clinical decision support software for management of chronic heart failure: Development and evaluation. *Comput Biol Med* 2006; 36:495-506.
18. Yan H, Jiang J, Zheng J, Peng C, Li Q. A multilayer perceptron based medical decision support system for heart disease diagnosis. *Expert Syst Appl* 2006; 30:272-281.
19. Ennett CM, Frize M, Walker CR. Influence of missing values on artificial network performance. *Medinfo* 2001, IOS press, 449-453.
20. The seventh report of the joint national committee on prevention, detection, evaluation, and treatment of high blood pressure NIH publication No. 04-5260, August 2004.
21. MacKay DJC. Bayesian interpolation. *Neural Compute* 1992; 4(3):415-447.
22. Foresee FD, Hagan MT. Gauss-Newton approximation to Bayesian regularization. *Proceedings of the International Joint Conference on Neural Networks* 1997:1930-1935.
23. Billings SA, Zheng GL. Radial basis function network configuration using genetic algorithms. *Neural Networks* 1995; 8(6):877-890.
24. Kubat M. Decision trees can initialize radial basis function networks. *IEEE Trans Neural Networks* 1998; 9(5):813-821.
25. Pedrycz W. Conditional fuzzy clustering in the design of radial basis function neural networks. *IEEE Trans Neural Networks* 1998; 9(4):601-612.
26. Zhang Z , Wang D , Harrington PB, Voorhees KJ, Rees J. Forward selection radial basis function networks applied to bacterial classification based on MALDI-TOF-MS. *Talanta* 2004;63:527-532.

27. Moody TJ, Darken CJ. Learning with localized receptive fields. Proceedings of connectionist models summer school, Morgan Kaufman Publishers, San Mateo 1989:133-143.
28. Schoonjans F, Zalata A, Depuydt CE, Comhaire FH. MedCalc: a new computer program for medical statistics. Comput Methods Programs Biomed 1995; 48(3):257-262.
29. Braunstein JB, Anderson GF, Gerstenblith G, Weller W, Niefeld M, Herbert R, et al. Non cardiac co morbidity increases preventable hospitalizations and mortality among medicare beneficiaries with chronic heart failure. J Am Coll Cardiol 2003; 42:1226-33.
30. Render ML, Weinstein AS, Blaustein AS. Left ventricular dysfunction in deteriorating patients with chronic obstructive pulmonary disease. Chest 1995;107:162-168.
31. Rutten FH, Cramer M-J M, Grobbee DE, Sachs APE, Kirkels JH, Lammers J-W J, et al. Unrecognized heart failure in elderly patients with stable chronic obstructive pulmonary disease. Eur Heart J 2005; 26:1887-1894.
32. Le Jemtel TH, Padeletti M, Jelic S. Diagnostic and therapeutic challenges in patients with coexistent chronic obstructive pulmonary disease and chronic heart failure. J Am Coll Cardiol 2007;49(2):171-80.